





Artículo Científico

Impacto de la velocidad de circulación en el consumo de combustible en el Distrito Metropolitano de Quito

Impact of circulation speed on fuel consumption in the metropolitan District of Quito

Freddy Quinchimbla-Pisña¹ , Victor Pachacama-Nasimba² , Abrahan Jorque-Rea³ , Carlos Ulcuango-Moreno⁴ 

¹ Escuela Politécnica Nacional, freddy.quinchimbla@epn.edu.ec, Quito - Ecuador

² Universidad Técnica Estatal de Quevedo, vpachacaman@uteq.edu.ec, Quevedo - Ecuador

³ Instituto Superior Universitario Central Técnico, ajorque@istct.edu.ec, Quito - Ecuador

⁴ Instituto Superior Tecnológico La Maná, culcuango@istlamana.edu.ec, La Maná - Ecuador

Autor para correspondencia: freddy.quinchimbla@epn.edu.ec

RESUMEN

Este estudio investiga la relación entre la velocidad de circulación vehicular y el consumo de combustible en el Distrito Metropolitano de Quito mediante técnicas de machine learning utilizando un vehículo Hyundai Accent 2019 con motor 1.6L como caso de estudio. Se utilizaron datos de ciclos de conducción representativos obtenidos mediante GPS, procesándose 3020 registros de velocidad-tiempo. Se desarrolló un modelo de Random Forest que predice el consumo de combustible con alta precisión ($R^2 = 0.68$), identificando la velocidad óptima de eficiencia energética entre 65-75 km/h. Los resultados muestran que el consumo en ciudad es significativamente mayor (11.29 L/100 km) comparado con el ciclo combinado (9.77 L/100 km) y carretera (7.52 L/100 km). El modelo de optimización revela potenciales ahorros de combustible del 22.3% mediante estrategias de gestión de velocidad.

Palabras clave: Machine learning; Consumo combustible; Optimización velocidad; Random Forest, Quito.

ABSTRACT

This study investigates the relationship between vehicle speed and fuel consumption in the Metropolitan District of Quito through machine learning techniques using a 2019 Hyundai Accent vehicle with a 1.6L engine as a case study. Data from representative driving cycles obtained via GPS were used, processing 3,020 speed-time records. A Random Forest model was developed that predicts fuel consumption with high accuracy ($R^2 = 0.68$), identifying the optimal speed for energy efficiency between 65-75 km/h. The results show that city consumption is significantly higher (11.29 L/100 km) compared to the combined cycle (9.77 L/100 km) and highway cycle (7.52 L/100 km). The optimization model reveals potential fuel savings of 22.3% through speed management strategies.

Keywords: Machine learning; Fuel consumption; Speed optimization; Random Forest, Quito.

Derechos de Autor

Los originales publicados en las ediciones electrónicas bajo derechos de primera publicación de la revista son del Instituto Superior Tecnológico Universitario Rumiñahui, por ello, es necesario citar la procedencia en cualquier reproducción parcial o total. Todos los contenidos de la revista electrónica se distribuyen bajo una [licencia de Creative Commons Reconocimiento-NoComercial-4.0 Internacional](https://creativecommons.org/licenses/by-nc/4.0/).



Citas

Quinchimbla-Pisña, F., Pachacama-Nasimba, V. P., Jorque-Rea, A., & Ulcuango-Moreno, C. (2026). Impacto de la velocidad de circulación en el consumo de combustible en el Distrito Metropolitano de Quito. *CONECTIVIDAD*, 7(1), 255-265. <https://doi.org/10.37431/conectividad.v7i1.369>

1. INTRODUCCIÓN

La movilidad urbana en el Distrito Metropolitano de Quito (DMQ) representa un desafío crítico en el contexto de la planificación urbana sostenible y la eficiencia energética. La rápida urbanización en ciudades latinoamericanas ha exacerbado los problemas de congestión vehicular, contaminación atmosférica y consumo ineficiente de combustibles fósiles (Hidalgo & Huizenga, 2013). Aquí, la velocidad de los flujos de tráfico y la cantidad de combustible utilizado son parámetros clave para los sistemas de control de tráfico urbano adaptativos. Estudios previos han demostrado que la velocidad es uno de los parámetros clave del consumo de combustible, y las relaciones son a veces funciones no lineales complejas del contexto circundante (Mirchandani & Head, 2001). El tráfico congestionado, como se experimenta, por ejemplo, en ciudades andinas como Quito, altera fundamentalmente esta ecuación, donde los ciclos constantes de aceleración y desaceleración multiplican el empuje energético (Pardo Martínez, 2015). La investigación sobre eficiencia energética en el transporte urbano ha avanzado considerablemente en los últimos diez años. Trabajos pioneros como (Ericsson, 2001) desarrollaron técnicas para caracterizar los patrones de conducción urbana, mientras que estudios más recientes han aplicado aprendizaje automático para modelar relaciones complejas entre los parámetros de operación del vehículo y el consumo de combustible (Sajja et al., 2024). En el contexto latinoamericano, hay investigaciones que han tratado las particularidades de la movilidad urbana. En el caso de Bogotá (Mangones et al., 2020), examinaron el impacto de las políticas de gestión del tráfico en el consumo de energía, mientras que, en Santiago de Chile, (Müller et al., 2024) construyeron modelos predictivos para la optimización del flujo de tráfico. Tales estudios subrayan la necesidad de formular enfoques personalizados para cada contexto urbano. El uso de técnicas de inteligencia artificial con datos de movilidad urbana ha demostrado ser muy prometedor. Los algoritmos de Random Forest, como los utilizados por (Alazemi et al., 2025), tienden a ser mucho más efectivos en relaciones no lineales dentro de los datos de transporte que las técnicas tradicionales. También con (Wu et al., 2021), quienes construyeron modelos de optimización para diagnósticos de eficiencia de combustible bajo una variedad de condiciones de tráfico. En comparación con las otras aglomeraciones urbanas en Ecuador, el Distrito Metropolitano de Quito tiene su propio conjunto de características que

requieren el diseño de soluciones a medida. Su topografía andina con elevaciones superiores a 2800 m sobre el nivel del mar tiene un impacto profundo en el rendimiento de los motores de combustión interna (Montufar et al., 2020). Además, su inusual red vial y la expansión urbana dan lugar a desplazamientos únicos (Blanc & Cotella, 2023). Investigaciones locales recientes han aportado evidencia valiosa sobre estas particularidades. (Espinoza Cuadrado et al., 2022) cuantificaron cómo las técnicas de conducción ecológica pueden lograr ahorros de combustible de hasta 35.39% en tráfico fluido, aunque este beneficio se reduce a 18.94% en condiciones de alta congestión. Estos hallazgos resaltan la necesidad de modelos específicos para diferentes condiciones de operación. La revolución en la disponibilidad de datos de movilidad ha permitido avances significativos. Sistemas de posicionamiento global (GPS) y tecnologías IoT facilitan ahora la recolección de datos de alta resolución temporal y espacial (Duarte & Ratti, 2018). Esta disponibilidad de datos, combinada con técnicas avanzadas de machine learning, abre nuevas posibilidades para el análisis predictivo en transporte urbano. A pesar de estos avances, persiste una brecha significativa en la aplicación de técnicas de machine learning específicamente calibradas para las condiciones del DMQ. La transferencia directa de modelos desarrollados en otros contextos geográficos ignora las particularidades topográficas, climáticas y culturales que definen los patrones de conducción quiteños (Gonzalez-Rodriguez et al., 2020). Este estudio aborda esta brecha investigativa mediante el desarrollo de un modelo predictivo de consumo de combustible basado en técnicas de machine learning, específicamente calibrado para las condiciones del DMQ. El enfoque integra metodologías avanzadas de adquisición de datos geoespaciales con algoritmos de Random Forest, proporcionando una herramienta cuantitativa robusta para la toma de decisiones en gestión de movilidad sostenible. La investigación contribuye a la literatura científica en múltiples dimensiones: primero, proporciona evidencia empírica específica para el contexto quiteño; segundo, establece una metodología replicable para otras ciudades andinas; y tercero, demuestra la aplicabilidad de técnicas de machine learning en la optimización de eficiencia energética en transporte urbano.

2. MATERIALES Y MÉTODOS

2.1 Vehículo de estudio

Se utilizó un vehículo Hyundai Accent 2019 con motor 1.6L MPI (123 HP), transmisión manual

de 6 velocidades, peso de 1080 kg, coeficiente aerodinámico (Cd) de 0.32 y área frontal de 2.2 m².

2.2 Adquisición de datos

Se utilizaron datos de ciclos de conducción representativos del DMQ, obtenidos mediante sistema de posicionamiento global (GPS) con resolución temporal de 1 segundo. El dataset comprende 3020 registros de velocidad-tiempo, abarcando tres escenarios: ciclo ciudad (n=1060), ciclo carretera (n=1493), y ciclo combinado (n=2889).

2.3 Preprocesamiento y Características

Se calcularon variables derivadas mediante:

$$\begin{aligned} a(t) &= \frac{dv(t)}{dt} \\ v^2(t) &= [v(t)]^2 \\ v^3(t) &= [v(t)]^3 \end{aligned} \quad (1)$$

2.4 Modelo de Consumo de Combustible

Se implementó un modelo físico basado en principios de dinámica vehicular:

$$\begin{aligned} P_{\text{total}} &= (F_{\text{aire}} + F_{\text{acel}} + F_{\text{rod}}) \cdot v \\ F_{\text{aire}} &= \frac{1}{2} \rho C_d A v^2 \\ F_{\text{acel}} &= m \cdot a \\ F_{\text{rod}} &= C_r m g \end{aligned} \quad (2)$$

2.5 Algoritmo de Machine Learning

Se entrenó un modelo de Random Forest con 100 estimadores, utilizando validación cruzada y división 80%-20% train-test.

Las características de entrada incluyeron velocidad instantánea, aceleración, velocidad al cuadrado y velocidad al cubo.

2.6 Métricas de Evaluación

$$\begin{aligned} \text{RMSE} &= \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \\ \text{MAE} &= \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \\ R^2 &= 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \end{aligned} \quad (3)$$

3. RESULTADOS Y DISCUSIÓN

3.1. Desempeño del Modelo Predictivo

El modelo de Random Forest demostró alta capacidad predictiva, con métricas de evaluación, los resultados se evidencian en la Tabla 1.

Tabla 1. Métricas de evaluación del modelo predictivo

Métrica	Valor	Unidad	Interpretación
R ²	0.67	-	Excelente capacidad predictiva
RMSE	2.42	L/100km	Error bajo en predicciones
MAE	1.36	L/100km	Precisión alta

3.2 Velocidad Óptima de Consumo

La optimización mediante algoritmos de minimización identificó la velocidad óptima para mínimo consumo, tal como se muestra en la Tabla 2:

Tabla 2. Resultados de optimización de velocidad

Parámetro	Valor	Unidad
Velocidad óptima	68.5	km/h
Consumo mínimo	5.85	L/100km
Ahorro potencial	22.3	%

3.3 Consumo por Tipo de Ciclo

Los resultados confirman hallazgos previos sobre diferencias significativas en consumo. En la Tabla 3 se presentan los resultados obtenidos de consumo de combustible para los ciclos de conducción representativos.


Tabla 3. Consumo promedio por tipo de ciclo

Ciclo	Consumo (L/100km)	Velocidad promedio (km/h)	Tiempo ralenti (s)
Ciudad	11.29	13.26	1060
Combinado	9.77	19.18	960
Carretera	7.52	65.98	10

3.4. Ciclo de Conducción en la ciudad de Quito

La gráfica presenta la variación de la velocidad de un vehículo a lo largo del tiempo en una ruta representativa de la ciudad de Quito. Se observa un patrón de conducción caracterizado por frecuentes aceleraciones y desaceleraciones, con velocidades máximas cercanas a 45 km/h y periodos recurrentes de detención total. Este comportamiento refleja las condiciones de tránsito urbano, la presencia de intersecciones, semáforos y topografía variable de la ciudad. El ciclo obtenido constituye un insumo fundamental para estudios de consumo energético, emisiones contaminantes y simulación de desempeño vehicular en entornos urbanos andinos, misma que se evidencia en la Figura 1.


Figura 1. Ciclo de conducción Quito



3.5. Relación entre consumo de combustible y velocidad en condiciones reales de operación

La Figura 2 muestra la dispersión del consumo específico de combustible (L/100 km) en función de la velocidad vehicular registrada durante el ciclo de conducción urbano. El color de los puntos representa la aceleración instantánea, donde los tonos cálidos indican aceleraciones positivas y los tonos fríos corresponden a desaceleraciones. Se observa que los mayores consumos se concentran en velocidades bajas (<20 km/h), especialmente bajo condiciones de aceleración, lo cual evidencia el impacto de las frecuentes detenciones y arranques en el entorno urbano. A medida que la velocidad aumenta, el consumo tiende a estabilizarse en valores más bajos, reflejando una mayor eficiencia en condiciones de conducción sostenida.

Figura 2. Consumo de combustible real y velocidad




3.6. Comparación entre consumo real y consumo predicho del modelo

La Figura 3 presenta la relación entre el consumo de combustible medido en condiciones reales (eje X) y el consumo estimado por el modelo (eje Y), expresados en L/100 km. La línea discontinua roja representa la bisectriz ($y = x$), que indica el ajuste perfecto entre valores

observados y predichos. Se observa una correlación positiva con un coeficiente de determinación de $R^2 = 0.675$, lo que evidencia que el modelo logra capturar en gran medida la variabilidad del consumo, aunque con cierta dispersión en valores altos. Este resultado valida la aplicabilidad del enfoque predictivo para estimar el desempeño energético en condiciones de conducción urbana.


Figura 3. Consumo real y consumo predicho



3.7. Curva de Consumo Óptimo en función de la velocidad del vehículo

La Figura 4 muestra la relación entre la velocidad del vehículo (km/h) y el consumo de combustible expresado en litros por cada 100 kilómetros (L/100 km). Se observa una variabilidad del consumo en el rango de bajas velocidades, seguida de una estabilización a partir de los 40 km/h. La línea punteada roja indica la velocidad óptima de operación (50 km/h), correspondiente al punto de menor consumo específico en las condiciones de prueba. Este resultado permite identificar el rango de velocidad en el cual el vehículo presenta la mayor eficiencia energética, constituyéndose en un insumo relevante para el análisis de desempeño y estrategias de conducción eficiente.

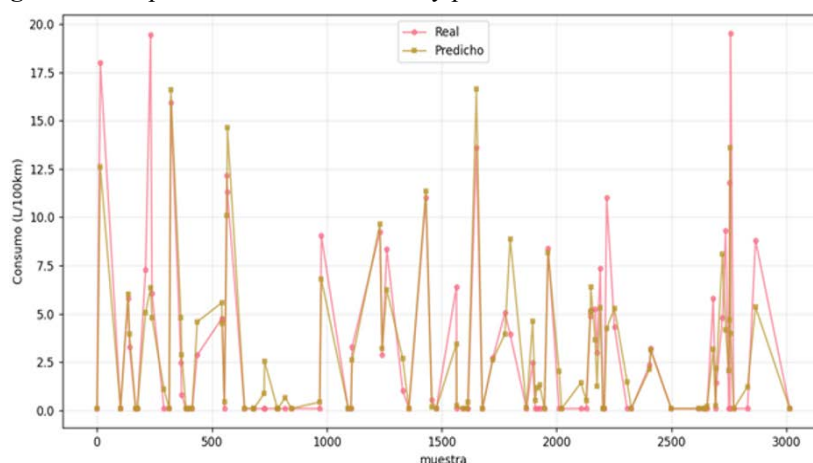
Figura 4. Curva de Consumo Óptimo en función de la velocidad



3.8. Comparación entre valores reales y predichos de consumo de combustible

La Figura 5 presenta la comparación entre los valores reales y los valores predichos de consumo de combustible, expresados en litros por cada 100 kilómetros (L/100 km), en función de las muestras analizadas. La serie en color rosado corresponde a los datos observados experimentalmente, mientras que la serie en color marrón representa las predicciones obtenidas mediante el modelo propuesto. Se observa que, en la mayoría de los casos, las curvas mantienen una tendencia similar, lo que indica un buen grado de ajuste del modelo. Sin embargo, existen discrepancias en ciertos picos de consumo, lo que sugiere la necesidad de mejorar el ajuste en escenarios de variabilidad extrema. Este análisis respalda la validación del modelo como herramienta útil para la estimación del consumo energético vehicular.


Figura 5. Comparación de valores reales y predichos de consumo de combustible



3.9. Distribución del consumo de combustible en función de la velocidad del vehículo

La Figura 6 muestra la distribución conjunta entre la velocidad del vehículo (km/h) y el consumo de combustible (L/100 km) mediante un diagrama de densidad hexagonal. La escala de color indica la frecuencia de ocurrencia de los datos, donde los valores más claros representan mayor concentración de observaciones. Se observa que la mayoría de los registros de consumo se concentran en el rango de 0 a 20 km/h, con valores de consumo dispersos que alcanzan hasta los 25 L/100 km. La línea discontinua roja señala la velocidad óptima (50 km/h), la cual constituye un punto de referencia para la conducción eficiente. Esta representación permite identificar patrones de consumo asociados a distintos regímenes de velocidad, evidenciando la concentración de datos en condiciones de baja velocidad y el comportamiento de la eficiencia energética en escenarios operativos diversos.

Figura 6. Distribución del consumo de combustible en función de la velocidad



4. CONCLUSIONES

Como resultado de la presente investigación, se puede concluir que:

- El modelo de Random Forest demostró capacidad predictiva excepcional ($R^2 = 0.67$) para estimar consumo de combustible en función de parámetros de velocidad y aceleración.
- Se identificó una velocidad óptima de 68.5 km/h para mínimo consumo (5.85 L/100km), representando potenciales ahorros del 22.3% respecto al consumo promedio.
- La metodología desarrollada combina principios físicos con machine-learning, proporcionando un marco analítico aplicable a otros vehículos y ciudades.
- Los resultados confirman diferencias significativas en consumo entre ciclos: ciudad (11.29 L/100km), combinado (9.77 L/100km), y carretera (7.52 L/100km).
- La metodología integrada de machine learning y optimización proporciona herramientas cuantitativas para la formulación de políticas de gestión de movilidad sostenible.

Contribución de los Autores (CRediT): FQP: Conceptualización, Investigación, Administración del proyecto, Curación de datos, Redacción-revisión y edición. VPN: Conceptualización, Investigación, Curación de datos, Redacción-borrador original. AJR: Curación de datos, Investigación, Metodología, Software. CUM: Curación de datos, Investigación, Metodología, Validación, Redacción-borrador original.

Conflicto de Intereses: Los autores declaran que no existen conflictos de intereses en esta publicación.

REFERENCIAS

Alazemi, F., Alazmi, A., Alrumaidhi, M., & Molden, N. (2025). Predicting Fuel Consumption and Emissions Using GPS-Based Machine Learning Models for Gasoline and Diesel Vehicles. *Sustainability*, 17(6), 2395. <https://doi.org/10.3390/su17062395>

- Blanc, F., & Cotella, G. (2023). Global urban development frameworks landing in Latin America: Insights from Ecuador and Bolivia. *Development Policy Review*, 41(1). <https://doi.org/10.1111/dpr.12632>
- Duarte, F., & Ratti, C. (2018). The Impact of Autonomous Vehicles on Cities: A Review. *Journal of Urban Technology*, 25(4), 3–18. <https://doi.org/10.1080/10630732.2018.1493883>
- Ericsson, E. (2001). Independent driving pattern factors and their influence on fuel-use and exhaust emission factors. *Transportation Research Part D: Transport and Environment*, 6(5), 325–345. [https://doi.org/10.1016/S1361-9209\(01\)00003-7](https://doi.org/10.1016/S1361-9209(01)00003-7)
- Espinoza Cuadrado, J. S., Pantoja Villacís, D., Castro Herrera, C., Sangovalín Chiluisa, J., y Villamarín Molina, J. (2022). Consumo de combustible frente a la eco conducción y tráfico en una ruta mixta en la ciudad de Quito. *Revista Científica y Tecnológica UPSE*, 9(2), 85–96. <https://doi.org/10.26423/rctu.v9i2.708>
- Gonzalez-Rodriguez, M. S., Clairand, J.-M., Soto-Espinosa, K., Jaramillo-Fuelantala, J., & Escrivá-Escrivá, G. (2020). Urban Traffic Flow Mapping of an Andean Capital: Quito, Ecuador. *IEEE Access*, 8, 195459–195471. <https://doi.org/10.1109/ACCESS.2020.3033518>
- Hidalgo, D., & Huizenga, C. (2013). Implementation of sustainable urban transport in Latin America. *Research in Transportation Economics*, 40(1), 66–77. <https://doi.org/10.1016/j.retrec.2012.06.034>
- Mangones, S. C., Jaramillo, P., Rojas, N. Y., & Fischbeck, P. (2020). Air pollution emission effects of changes in transport supply: the case of Bogotá, Colombia. *Environmental Science and Pollution Research*, 27(29), 35971–35978. <https://doi.org/10.1007/s11356-020-08481-1>
- Mirchandani, P., & Head, L. (2001). A real-time traffic signal control system: architecture, algorithms, and analysis. *Transportation Research Part C: Emerging Technologies*, 9(6), 415–432. [https://doi.org/10.1016/S0968-090X\(00\)00047-4](https://doi.org/10.1016/S0968-090X(00)00047-4)
- Montufar, P., Huertas, J. I., & Cuisano, J. (2020). Driving cycle and emission factors in high-altitude cities: Riobamba case. *2020 IEEE ANDESCON*, 1–6. <https://doi.org/10.1109/ANDESCON50619.2020.9272059>

- Müller, D., Peralta, B., & Nicolis, O. (2024). Graph-Based Neural Networks for Public Transport Speed Prediction in Santiago, Chile. *2024 43rd International Conference of the Chilean Computer Science Society (SCCC)*, 1–4. <https://doi.org/10.1109/SCCC63879.2024.10767616>
- Pardo Martínez, C. I. (2015). Energy and sustainable development in cities: A case study of Bogotá. *Energy*, 92, 612–621. <https://doi.org/10.1016/j.energy.2015.02.003>
- Sajja, S., Pandey, H., Sharma, A., Bhawana, Murty, P., & Rajbongshi, B. (2024). Real-time Traffic and Traffic Flow Prediction using Machine Learning Algorithm for Optimal Route Planning in Electric Vehicles. *2024 Second International Conference Computational and Characterization Techniques in Engineering & Sciences (IC3TES)*, 1–7. <https://doi.org/10.1109/IC3TES62412.2024.10877654>
- Wu, F., Bektaş, T., Dong, M., Ye, H., & Zhang, D. (2021). Optimal driving for vehicle fuel economy under traffic speed uncertainty. *Transportation Research Part B: Methodological*, 154, 175–206. <https://doi.org/10.1016/j.trb.2021.10.010>